

‘Eigenfaces de Imagen Reducida’ para el Reconocimiento Automático de Rostros

Franco Chichizola¹, Armando De Giusti², Marcelo Naiouf³

Instituto de Investigación en Informática LIDI.⁴

Facultad de Informática. Universidad Nacional de La Plata.

Resumen

En este trabajo se presenta un nuevo algoritmo para el reconocimiento automático de rostros *Eigenfaces de Imagen Reducida* basado en el modelo *Eigenfaces* buscando mejorar el porcentaje de reconocimiento.

Se desarrollaron dos algoritmos diferentes del método original de Eigenfaces para comparar los resultados obtenidos por el nuevo modelo bajo distintas condiciones, como lo son la cantidad de personas, y la cantidad de fotos de cada una de ellas. En la experimentación se utilizó una base de datos limitada de imágenes que han sido normalizadas internacionalmente.

Con este método presentado se logran dos importantes ventajas con respecto a los modelos anteriores: se mejora el porcentaje de aciertos en el reconocimiento, y permite trabajar con un conjunto de imágenes mayor para el entrenamiento.

Palabras Claves

Reducción de la imagen – Reconocimiento de Patrones – Análisis de Componente Principal Eigenfaces – Rostros.

1. Introducción

Se puede pensar en numerosas aplicaciones en las cuales se necesite del reconocimiento de rostros en forma automática. Por ejemplo, en un sistema de seguridad de acceso a lugares físicos o electrónicos; para la identificación de personas en los archivos policiales de delincuentes; o también combinado con otros métodos de reconocimiento más costosos como el de huellas digitales, reduciendo el conjunto de posibles candidatos. Para esto se debe contar con un sistema que permita maximizar la cantidad de aciertos, o minimizar la cantidad de reconocimientos fallidos, dependiendo de la aplicación.

Para cualquiera de los usos el objetivo es obtener un sistema de reconocimiento de rostros automático que sea tolerante a diferentes variaciones en las imágenes como posición, características

¹ Licenciado en Informática. Becario UNLP. Ayudante Diplomado.III-LIDI. Facultad de Informática. UNLP. francoch@lidi.info.unlp.edu.ar.

² Investigador Principal CONICET. Profesor Titular Ded. Exclusiva.III-LIDI. degiusti@lidi.info.unlp.edu.ar.

³ Profesor Titular DE. III-LIDI. Fac.de Informática. UNLP. mnaiouf@lidi.info.unlp.edu.ar.

⁴ III-LIDI miembro del Instituto de Investigación en Ciencia y Tecnología Informática (IICyTI) - Facultad de Informática. UNLP - Calle 50 y 115 1er Piso, (1900) La Plata, Argentina. TE/Fax +(54) (221) 422-7707. <http://lidi.info.unlp.edu.ar>

de los rostros, e iluminación. El mismo debe funcionar tanto para aplicaciones de alta seguridad (minimizar fallos), como para aquellas que sirven para reducir el conjunto de posibles candidatos (maximizar aciertos).

El reconocimiento de rostros involucra las siguientes etapas:

- **Entrenamiento:** consiste en utilizar algún mecanismo que le permita al sistema “aprender” los rostros que constituyen el conjunto de entrenamiento. El tipo de entrenamiento que sea utilizado para el aprendizaje dependerá, en gran medida, de la metodología que se esté utilizando para el reconocimiento.
- **Reconocimiento:** básicamente consiste en alimentar al sistema con diferentes imágenes de personas, esperando obtener como resultado una forma de codificación unívoca que permita identificar de qué persona se trata, o bien determinar que el rostro no está en la base de conocimiento.

Para la implementación de este tipo de sistemas, independientemente de la técnica o metodología que sea implementada, están involucrados dos conjuntos de datos. El primero es utilizado durante la etapa de aprendizaje, el cual es comúnmente llamado *conjunto de entrenamiento*.

El segundo conjunto de rostros, es el que se utiliza durante la etapa de reconocimiento y es llamado *conjunto de prueba*.

Uno de los modelos de reconocimiento de rostros más utilizado es el Análisis de Componente Principal o *Eigenfaces* [6][7][8][13], el cual está basado en las propiedades matemáticas de la imagen digitalizada, que captura características invariantes de los rostros. Es interesante estudiar y analizar esta técnica por los siguientes motivos:

- Aparente simplicidad de implementación contra buenos resultados en grandes bases de datos.
- Es una técnica resistente a variaciones mencionadas anteriormente.
- Se realiza bajo un proceso netamente automático.

Con el objetivo de lograr un mayor rendimiento en el reconocimiento se desarrolló un nuevo algoritmo basado en este modelo (PCA) y se comparó con dos implementaciones diferentes de Eigenfaces.

2. Análisis de Componente Principal (PCA) – “Eigenfaces”

El éxito de una metodología de reconocimiento de rostros depende fuertemente de los elementos utilizados para representar las imágenes para su posterior clasificación. El patrón que represente a una imagen debe estar compuesto por los elementos más sobresalientes de ella, permitiendo reducir la cantidad de datos usados en el proceso de clasificación, y aumentar la diferencia entre ellas para que actúe como un poderoso discriminante o clasificador. Una de las técnicas más utilizadas para seleccionar un subconjunto de elementos que cumpla con esas condiciones es el Análisis de Componente Principal (PCA), la cual genera un conjunto de vectores ortonormales que maximizan la dispersión entre todas las muestras proyectadas, reduciendo al mismo tiempo su dimensión. Los primeros en usar esta metodología para representar imágenes de caras fueron Kirby y Sirovich [7], y para reconocimiento de rostros Turk y Pentland [6][8].

2.1 Algoritmo Original de Eigenfaces

En primera instancia se desarrolló un sistema de reconocimiento de rostros basado en el algoritmo básico de *eigenfaces* [9][10][11].

Tanto la etapa de entrenamiento como la de reconocimiento utilizan una base de rostros compuesta por un conjunto $\Gamma_1, \Gamma_2, \dots, \Gamma_X$ de imágenes de dimensión $N \times N$.

El **entrenamiento** consiste en los siguientes pasos:

1. Cada imagen

$$\Gamma_i \text{ con } i = 1, 2, \dots, M$$

es reorganizada como un vector de dimensión N^2 cuyo valor es construido como la concatenación de cada una de las filas de la imagen, formando así una matriz de $N^2 \times M$.

2. Se obtiene el rostro promedio Ψ según la fórmula

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n$$

3. El rostro promedio Ψ obtenido es restado a cada una de las imágenes Γ_i con i entre $1..M$ obteniendo un nuevo conjunto de vectores

$$\Phi_i = \Gamma_i - \Psi$$

que conforman la matriz $\Lambda = [\Phi_1, \Phi_2, \dots, \Phi_M]$ de $N^2 \times M$.

4. En este punto se buscan los autovectores de la matriz de covarianza de Λ

$$C = \frac{1}{N^2} \Lambda \Lambda^T$$

de dimensión $N^2 \times N^2$. Estos vectores propios son los vectores ortonormales usados para construir la representación de las imágenes. El tamaño de la matriz C hace intratable este paso por el espacio y el tiempo requerido). Para solucionar este problema, se obtiene una aproximación de dichos vectores.

- a. Se obtienen la matriz de covarianza reducida

$$L = \frac{1}{M} \Lambda^T \Lambda$$

de dimensiones $M \times M$.

- b. Se obtienen los autovectores de L , los que ordenados de mayor a menor según sus correspondientes autovalores, conforman la matriz v .
- c. Se aproximan los autovectores C

$$u = \Lambda v$$

donde cada columna de u representa un vector propio.

5. Se obtiene el patrón

$$\Omega_i^T = [\omega_1, \omega_2, \dots, \omega_M] \text{ con } i = 1, 2, \dots, M$$

donde

$$\omega_k = u_k^T (\Gamma_i - \Psi) \text{ con } k = 1, 2, \dots, M$$

Dada la imagen de un rostro como entrada del sistema, el proceso de **reconocimiento** intenta encontrar en la base de imágenes, aquella que se corresponde con el rostro dado, para lo cual se calcula su patrón Ω utilizando el mismo procedimiento anteriormente descrito, y se busca la distancia mínima

$$\min(\|\Omega - \Omega_i\|^2) \text{ con } i = 1, 2, \dots, M$$

Una vez encontrada la distancia mínima se indica cuál es la imagen correspondiente.

2.2 Eigenfaces normalizados

Para que el resultado final del reconocimiento no se vea afectado solo por las zonas de las imágenes donde el orden de magnitud de los vectores propios es mayor, se realizó una modificación en el paso 4:

- a. Se obtiene la matriz de covarianza reducida

$$L = \Lambda^T \Lambda$$

de dimensiones $M \times M$.

- b. Se obtienen los autovectores de L , los que ordenados de mayor a menor según sus correspondientes autovalores, conforman la matriz v .
- c. Se aproximan los autovectores C

$$u = \Lambda v$$

- d. Se normalizan los autovectores a través de la norma de cada uno de ellos

$$u_k = \frac{u_k}{\text{norm}(u_k)}$$

$$\text{norm}(x) = \sqrt{\sum_{i=1}^{|N|} x_i^2} \quad \text{con } |N| = \text{cantidad de elementos de } x$$

2.3 Eigenfaces de Imagen Reducida

Como se especificó en el paso 4 del algoritmo original (2.1), se buscan los autovectores de la matriz de covarianza. Debido a su gran dimensión estos deben ser aproximados a través de los vectores propios de la matriz de covarianza reducida. En este trabajo se propone un nuevo método que consiste en formar una imagen de menor tamaño que permita obtenerlos directamente.

El entrenamiento consiste en los siguiente pasos:

- 1- Cada imagen es dividida en bloques de $P \times P$. Cada uno de estos bloques se promedia y se obtiene una nueva imagen de $D \times D$, con $D = N / P$, que se obtiene de reemplazar cada bloque por su promedio.
- 2- Cada imagen Γ_i con $i = 1, 2, \dots, M$ es reorganizada como un vector de dimensión D^2 cuyo valor es construido como la concatenación de cada una de las filas de la imagen, formando así una matriz de $D^2 \times M$.
- 3- Se obtiene el rostro promedio Ψ según la fórmula

$$\Psi = \frac{1}{M} \sum_{n=1}^M \Gamma_n$$

- 4- El rostro promedio Ψ obtenido es restado a cada una de las imágenes Γ_i con $i = 1..M$ obteniendo un nuevo conjunto de vectores $\Phi_i = \Gamma_i - \Psi$ que conforman la matriz

$$\Lambda = [\Phi_1, \Phi_2, \dots, \Phi_M] \text{ de } D^2 \times M.$$

- 5- Se obtiene la matriz de covarianza

$$C = \frac{1}{D^2} \Lambda \Lambda^T$$

de dimensiones $D^2 \times D^2$.

- 6- Se obtienen los autovectores de C , los que ordenados de mayor a menor según sus correspondientes autovalores, conforman la matriz u .

7- Se obtiene el patrón

$$\Omega_i^T = [\omega_1, \omega_2, \dots, \omega_M] \text{ con } i = 1, 2, \dots, M$$

donde

$$\omega_k = u_k^T (\Gamma_i - \Psi) \text{ con } k = 1, 2, \dots, D^2.$$

El proceso de **reconocimiento** es semejante al de los modelos anteriores, dada la imagen de un rostro como entrada del sistema se calcula su patrón Ω usando el procedimiento antes descrito y se busca la distancia mínima.

$$\min(\|\Omega - \Omega_i\|^2) \text{ con } i = 1, 2, \dots, M$$

3. Experimentación

En este trabajo se incluyeron dos tipos de experimentos para comparar el método propuesto (2.3) con las dos variantes del PCA anteriormente definidas (2.1 y 2.2), y determinar cómo se comporta bajo distintas condiciones. Para todas las pruebas realizadas se usó la “Base de Datos de Rostros ORL” [14], la cual contiene un conjunto de 40 personas, con 10 fotos de la cara de cada una de ellas, tomadas entre abril de 1992 y abril de 1994 en el Laboratorio AT&T de Cambridge. Las imágenes de esta base están en niveles de gris, y se modificaron para dejarlas con un tamaño de 100x100 pixels.

En todos los casos, se utilizó un subconjunto de fotos como *Conjunto de Entrenamiento*, y el resto de las imágenes de las personas que están en él como *Conjunto de Prueba*. Para cada tipo de prueba se muestra el peor caso, el mejor, el promedio, y el promedio podado (sacando los casos extremos), tanto en cantidad como en porcentaje de reconocimientos.

3.1 Pruebas con una foto por persona

Se realizaron pruebas con *conjuntos de entrenamiento* con distinta cantidad de personas (5, 10, 20 y 40), usando una foto por cada una de ellas. En todos los casos se probaron los tres algoritmos con las mismas combinaciones de personas. Para el caso del algoritmo “*Eigenfaces de Imagen Reducida*” (2.3), las pruebas se hicieron con dos niveles de reducción diferentes (tamaño de los bloques o P), 10 y 5, los cuales se determinaron a través de pruebas realizadas, logrando el tamaño de bloque 5 como óptimo para este conjunto de imágenes [15].

Para cada uno de los tamaños probados (excepto con 40 personas) se usaron 30 combinaciones diferentes en el conjunto de entrenamiento.

El conjunto de pruebas de cada experimento constó de las 9 imágenes restantes de cada persona perteneciente al conjunto de entrenamiento.

3.1.1 Entrenamiento con 5 personas

El conjunto de prueba constó de 45 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	31	68.89	39	86.67	44	97.78	40	88.89
Normalizado	34	75.56	40	88.89	44	97.78	40	88.89
Reducida (P=10)	34	75.56	40	88.89	45	100	41	91.11
Reducida (P=5)	35	77.78	41	91.11	45	100	42	93.33

3.1.2 Entrenamiento con 10 personas

El conjunto de prueba constó de 90 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	59	65.56	71	78.89	82	91.11	72	80
Normalizado	64	71.11	75	83.33	81	90	75	83.33
Reducida (P=10)	65	72.22	76	84.44	85	94.44	76	84.44
Reducida (P=5)	67	74.44	77	85.56	85	94.44	79	87.78

3.1.3 Entrenamiento con 20 personas

El conjunto de prueba constó de 180 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	112	62.22	124	68.89	147	81.67	123	68.33
Normalizado	121	67.22	137	76.11	156	86.67	136	75.56
Reducida (P=10)	127	70.56	139	77.22	155	86.11	140	77.78
Reducida (P=5)	129	71.67	141	78.33	159	88.33	142	78.89



3.1.4 Entrenamiento con 40 personas

Se realizaron 10 pruebas (para cada algoritmo) con las 40 personas. Una por cada una de las 10 fotos diferentes de los sujetos. El conjunto de prueba constó de las 360 fotos restantes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	202	56.11	219	60.83	233	64.72	226	62.78
Normalizado	233	64.72	249	69.17	260	72.22	250	69.44
Reducida (P=10)	236	65.56	251	69.72	264	73.33	252	70
Reducida (P=5)	239	66.39	253	70.28	261	72.5	256	71.11

3.1.5 Gráficos resumen

En los siguientes gráficos se muestra en forma resumida la variación en el porcentaje de acierto (mejor caso y media podada) entre los distintos métodos para una misma cantidad de fotos en la base, y como se modifica según se incrementa esa cantidad.



3.2 Pruebas con varias fotos por persona

En estas pruebas se usaron más de una foto para cada persona del conjunto de entrenamiento (2, 3, 4, 5, 6, 7, 8 y 9). Las pruebas se orientaron al conjunto de mayor tamaño (40 personas diferentes) que son las que más problemas ocasionan. En todos los casos (excepto en el de 9 fotos por persona) se realizaron 20 pruebas para cada algoritmo con diferentes combinaciones de imágenes, las cuales varían en la orientación de la cara.

Para el caso del algoritmo “*Eigenfaces de Imagen Reducida*” (2.3), las pruebas también se realizaron con dos niveles de reducción diferentes.

Para el conjunto de prueba se usaron todas las imágenes restantes.

Con las pruebas que contenían 5 o más fotos por persona solo se pudo probar el algoritmo “*Eigenfaces de Imagen Reducida*” debido a que la excesiva memoria requerida en las otras dos implementaciones (2.1 y 2.2) hicieron imposible su ejecución.

3.2.1 Dos fotos por persona

Para el conjunto de prueba se usaron 320 imágenes restantes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	218	68.13	236	73.75	252	78.75	235	73.44
Normalizado	248	77.5	265	82.81	281	87.81	264	82.5
Reducida (P=10)	244	76.25	265	82.81	281	87.81	265	82.81
Reducida (P=5)	247	77.19	266	83.13	283	88.44	266	83.13

3.2.2 Tres fotos por persona

Para el conjunto de prueba se usaron 280 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	219	78.21	234	83.57	247	88.21	236	84.29
Normalizado	231	82.5	248	88.57	261	93.21	251	89.64
Reducida (P=10)	233	83.21	252	90	265	94.64	255	91.07
Reducida (P=5)	235	83.93	253	90.36	265	94.64	258	92.14

3.2.3 Cuatro fotos por persona

Para el conjunto de prueba se usaron 240 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	186	77.5	203	84.58	215	89.58	207	86.25
Normalizado	201	83.75	220	91.67	229	95.42	223	92.92
Reducida (P=10)	204	85	222	92.5	233	97.08	225	93.75
Reducida (P=5)	208	86.67	225	93.75	233	97.08	227	94.58

3.2.4 Cinco fotos por persona

Para el conjunto de prueba se usaron 200 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	--	--	--	--	--	--	--	--
Normalizado	--	--	--	--	--	--	--	--
Reducida (P=10)	179	89.5	187	93.5	195	97.5	187	93.5
Reducida (P=5)	180	90	189	94.5	197	98.5	189	94.5

3.2.5 Seis fotos por persona

Para el conjunto de prueba se usaron 160 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	--	--	--	--	--	--	--	--
Normalizado	--	--	--	--	--	--	--	--
Reducida (P=10)	147	91.88	153	95.63	159	99.38	153	95.63
Reducida (P=5)	149	93.13	154	96.25	159	99.38	154	96.25

3.2.6 Siete fotos por persona

Para el conjunto de prueba se usaron 120 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	--	--	--	--	--	--	--	--
Normalizado	--	--	--	--	--	--	--	--
Reducida (P=10)	112	93.33	116	96.67	120	100	117	97.5
Reducida (P=5)	115	95.83	118	98.33	120	100	118	98.33

3.2.7 Ocho fotos por persona

Para el conjunto de prueba se usaron 80 imágenes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	--	--	--	--	--	--	--	--
Normalizado	--	--	--	--	--	--	--	--
Reducida (P=10)	74	92.5	77	96.25	80	100	77	96.25
Reducida (P=5)	76	95	78	97.5	80	100	78	97.5



3.2.8 Nueve fotos por persona

En este caso se hicieron 10 pruebas (para cada algoritmo) con las distintas combinaciones de nueve fotos de cada una de las 40 personas para formar el conjunto de entrenamiento. Para el conjunto de prueba se usaron las 40 imágenes restantes.

Caso Algoritmo	Peor		Promedio		Mejor		Media Podada	
	Cantidad	%	Cantidad	%	Cantidad	%	Cantidad	%
Original	--	--	--	--	--	--	--	--
Normalizado	--	--	--	--	--	--	--	--
Reducida (P=10)	38	95	40	100	40	100	40	100
Reducida (P=5)	39	97.5	40	100	40	100	40	100

3.2.9 Gráficos resumen

Los gráficos que se muestran a continuación son un resumen de los porcentajes de aciertos (mejor caso y media podada) entre los distintos métodos de acuerdo a la cantidad de fotos por persona que se utilizan en el conjunto de entrenamiento.



4. Conclusiones

De acuerdo a los resultados obtenidos en la primera prueba, se puede concluir que el método propuesto brinda una importante mejora con respecto al algoritmo original. Esta diferencia es más significativa a medida que aumenta la cantidad de personas en el conjunto de entrenamiento. Al compararlo con el normalizado la mejoría no es tan notoria, sobre todo cuando la imagen se reduce en bloques de tamaño 10, donde los resultados son muy parejos. Si se habla de bloques de tamaño 5 continua existiendo una mejora pero no tan abultada como en el caso del método original.

Con las pruebas realizadas en la segunda parte, se puede observar que aumenta el porcentaje de reconocimientos a medida que se incrementa la cantidad de fotos (de cada persona) utilizadas para el entrenamiento. Sin importar el método utilizado la mejora es notoria y similar en todos ellos (el porcentaje incrementado).

Al mismo tiempo, se comprueba que este nuevo algoritmo permite trabajar con muchas más imágenes en el conjunto de entrenamiento que las implementaciones anteriores, con lo cual se puede mejorar el porcentaje de aciertos al usar más fotos de cada persona, o bien incrementar la cantidad de sujetos que se quieran reconocer.

De las dos pruebas combinadas se concluye que el método propuesto (“Eigenfaces de Imagen Reducida”) con tamaño de bloque 5, es el que mejores resultados promedio produce. Como contrapartida surge el incremento en el tiempo necesario para realizar el aprendizaje, el cual es más notorio cuando menor es la cantidad de imágenes en el conjunto de entrenamiento. Algo similar ocurre con el tiempo necesario para la etapa de reconocimiento, pero dado que este tiempo es varios ordenes de magnitud menor que en el aprendizaje, no se le presta tanta atención. Teniendo en cuenta la necesidad de lograr una respuesta más rápida surge la idea de paralelizar este algoritmo [16][17][18][19].

5. Referencias

- [1] S. Lin, S. kung, y L. Lin, “Face Recognition/Detection by Probabilistic Decision-Based Neural Network”, *IEEE Trans. Neural Networks*, vol. 8, pp. 114-132, 1997.
- [2] Steve Lawrence, C. Lee Giles , Ah Chung Tsoi, Andrew D. Back “Face Recognition: A Convolutional Neural Network Approach”. *IEEE Transactions on Neural Networks, Special Issue on Neural Networks and Pattern Recognition*, Volume 8, Number 1, pp. 98-113, 1997.
- [3] F. Samaria and S. Young, “HMM based architectures for face identification”, *Image and Computer Vision*, vol. 12, pp 537-583, October 1994
- [4] F. Samaria, “Face Recognition Using Hidden Markov Models”, PhD thesis, University of Cambridge, Cambridge, U.K. 1994.
- [5] Laurenz Wiskott, Jean-Marc Fellous, Norbert Krüger and Christoph von der Malsburg “*Face Recognition by Elastic Bunch Graph Matching*”, in *Intelligent Biometric Techniques in Fingerprint and Face Recognition*, eds. L.C. Jain et al., publ. CRC Press, ISBN 0-8493-2055-0, Chapter 11, pp. 355-396, (1999)
- [6] M. Turk and A. Pentland, “Face recognition using eigenfaces”, in *Proceedings of International Conference on Pattern Recognition* , pp. 586-591,1991
- [7] M. Kirby and L. Sirovich. “Application of the karhunen-loeve procedure for the characterization of human faces”. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 12(1):103–108, 1990.
- [8] M. Turk and A. Pentland. “Eigenfaces for recognition”. *Journal of Cognitive Neuroscience*, 13(1):71–86, 1991.
- [9] Correa Martín Sebastián y Chichizola Franco. Trabajo de grado de Licenciatura en Informática “Sistema de Reconocimiento de Rostros”. 2001.
- [10] Correa M. S., Chichizola F., De Giusti A. E. y Naiouf M. “Sistema de Reconocimiento de Rostros”. *Proceeding del VII Congreso Argentino de Ciencias de la Computación (CACIC’01)*. Calafate, Santa Cruz, Argentina. Octubre de 2001.
- [11] Chichizola F., De Giusti A. E. y Naiouf M. “Reconocimiento de Rostros”. *IV Workshop de Investigadores de Ciencias de la Computación (WICC’02)*. Bahía Blanca, Buenos Aires, Argentina.
- [12] Jose Gerardo Gonzalez, “*Face Recognition and Detection Using Eigenfaces*”, 1997
- [13] MIT Media Laboratory Vision and Modeling Group (VISMOD) Face Recognition Demo Page <http://www-white.media.mit.edu/vismod/demos/facerec/>
- [14] AT&T Laboratories Cambridge, “The ORL Database of Faces”, ftp://ftp.uk.research.att.com/pub/data/att_faces.zip <http://www.cam-orl.co.uk/facedatabase.html>

- [15] Chichizola Franco, “Reconocimiento de Rostros de la imagen reducida por bloques”. Informe técnico LIDI. Marzo 2003.
- [16] Champredonde Raúl y Chichizola Franco, “Parallelizing algorithms in ADA on Clementina II Face Recognition System”. Proceeding del VII Congreso Argentino de Ciencias de la Computación (CACIC’01). Calafate, Santa Cruz, Argentina. Octubre de 2001.
- [17] Champredonde Raúl y Chichizola Franco, “Eigenvectors and Eigenvalues Computation Parallelization in a Shared-Memory Model”. Proceeding del VIII Congreso Argentino de Ciencias de la Computación (CACIC’02). Capital Federal, Argentina. Octubre de 2002.
- [18] Champredonde Raúl y Chichizola Franco, “Paralelización de Eigenfaces en un esquema de memoria compartida”. Workshop de Sistemas Distribuido y Paralelismo (WSDP). Jornadas Chilenas de Computación 2002. Noviembre de 2002.
- [19] Champredonde Raúl y Chichizola Franco, “Paralelización del Cálculo de Autovalores y Autovectores en un esquema de Memoria Compartida”. XXVIII Conferencia Latinoamericana de Informática (CLEI’02). Montevideo, Uruguay. Noviembre de 2002.